

Prediction of flood occurrence in the Torogh Dam watershed, located in Khorasan Razavi Province

Majid Goodarzi*¹ , Zahra Soltani² , Farkhondeh Hashemi Ghandali³

1- (*Corresponding author) Associate professor of geography and urban planning, Shahid Chamran University of Ahvaz, Ahvaz, Iran. Email: m.goodarzi@scu.ac.ir

2- Associate professor of geography and rural planning, Shahid Chamran University of Ahvaz, Ahvaz, Iran, Email: z.soltani@scu.ac.ir

3- Ph.D. Student of geography and urban planning, Shahid Chamran University of Ahvaz, Ahvaz, Iran, Email: f.hashemi1401@gmail.com

Article Info

Date of receive:

2025/02/01

Date of last review:

2026/01/04

Date of accept:

2026/01/04

Date of online publication:

2026/01/07

Keywords:

Natural hazards,
Water resources
management,
Artificial Neural
Networks,
Khorasan Razavi
Province

Extended Abstract

Introduction

Watersheds, as fundamental units of water resources management, possess unique characteristics that influence the occurrence and intensity of floods. In Iran, where the climate is predominantly arid and semi-arid, flood events, particularly in small to medium-sized watersheds like the Torogh Dam watershed, pose significant challenges for water resource management. The Torogh Dam, located in Khorasan Razavi Province near the city of Mashhad, plays a vital role in supplying drinking and agricultural water to the region. Sudden flood events in this watershed can negatively impact the dam's water storage, the safety of downstream areas, and local infrastructure. Therefore, the development of precise and efficient forecasting tools is essential for managing this watershed effectively.

Materials and Methods

To predict floods in the Torogh Dam watershed, Artificial Neural Networks (ANNs) were utilized as a powerful computational tool. This approach involved various stages, including data collection, data processing, and modeling using deep learning algorithms. The methodology for this study is outlined as follows:

Selection of the Study Area: The Torogh Dam watershed, located in Razavi Khorasan Province, was selected due to its unique physiographic and hydrological characteristics and its economic significance. With a concentration time of less than three hours, this watershed provides suitable conditions for evaluating the performance of ANN models in flood forecasting. ... ► Page 28

How to Cite:

Goodarzi, M. Soltani, Z. Hashemi Ghandali, F. (2026). Prediction of flood occurrence in the Torogh dam watershed, located in Khorasan Razavi Province. Scientific-Research Quarterly Geographical Data (SEPEHR). 35(137), 27-44.

Data Collection

The data utilized in this study comprised meteorological data (such as precipitation and temperature), hydrological data (streamflow), and physiographic data of the watershed (e.g., area, slope, and river length). Precipitation data were collected daily from reliable meteorological stations and subjected to quality assessments. Statistical methods were applied to correct and fill missing data, minimizing uncertainties in the dataset.

Data Preprocessing

To enhance the accuracy of the model, raw data were normalized during preprocessing to ensure all inputs fell within a specified numerical range. Additionally, only precipitation data from one or two days prior to flood events were included in the model to more accurately account for temporal dependencies.

Design of the Artificial Neural Network Model

The ANN used in this study consisted of two primary structures:

Two-Layer Network: This structure included an input layer, a single hidden layer, and an output layer. The number of neurons in the hidden layer was determined through trial and error to achieve optimal results.

Three-Layer Network: This structure featured two hidden layers and an output layer, designed to improve accuracy and increase the model's regression performance.

In both structures, modeling parameters, such as the number of neurons and learning rate, were optimized. The backpropagation algorithm was employed as the learning method.

Model Training and Evaluation

The data were divided into two sets: a training set (70% of the data) and a test set (30% of the data). The models were trained using the training set, and their performance was evaluated with the test set. Evaluation metrics included the coefficient of determination (R^2), Mean Absolute Error (MAE), and Root Mean Squared Error (RMSE).

Output Analysis

The results indicated that using only precipitation data from the day of the flood and the previous day was sufficient due to the short concentration time of the watershed. Increasing the number of neurons in both the two-layer and three-layer networks improved the prediction accuracy, particularly when only precipitation data from the two most recent days were used as inputs to the network.

Results and discussion

In two-layer networks, it is observed that when

the transfer function of the first layer is Tansig and that of the second layer is Purelin, and precipitation intensity is considered only for the day of the flood and the previous day, the network's output demonstrates a direct relationship with the target and aligns more closely with reality. Increasing the number of neurons under this configuration further improves the results, particularly in both the training and generalization phases. In three-layer networks with a T-T-T transfer function arrangement, increasing the number of neurons enhances regression performance, resulting in outputs that more accurately match reality. This is especially true when precipitation intensity is limited to the day of the flood and the preceding day. In the same three-layer networks, when the number of neurons in the first layer is set to 10 and in the second layer to 15, and the transfer function arrangement is P-T-P, results become more realistic when using only single-day precipitation intensity as input. When the number of layers increases to four, it is observed that if the transfer function for all four layers is Tansig, the outputs of the network matrix and the target exhibit an inverse relationship. Therefore, it is recommended to adopt a configuration in which the last two layers utilize the Purelin transfer function. By transitioning to a cascade-forward network structure, it is observed that a four-layer network with a P-T-P-P transfer function arrangement maintains a consistent direct relationship in most cases except for validation. However, this relationship deteriorates when considering precipitation intensity from the past two days.

Conclusion

In conclusion, given the short concentration time of watersheds, accounting only for the precipitation intensity on the day of the flood and the preceding day is sufficient. This has been confirmed in practice in most cases. Additionally, networks perform better when using a Purelin transfer function in the initial layers and a Tansig transfer function in the final layers. Therefore, it is recommended to configure the transfer functions accordingly. For cascade-forward networks, it is preferable to use the Tansig transfer function in the middle layers, while for backpropagation networks, using the Tansig transfer function in the initial layers yields better results. Furthermore, for flood calculations, it is advisable to utilize three-layer or four-layer backpropagation networks, or four-layer cascade-forward networks, as their outputs are closer to the expected real-world values.



صفحات ۴۴ - ۲۷

فصلنامه علمی - پژوهشی

اطلاعات جغرافیایی (سپهر) دوره ۳۵، شماره ۱۳۷، بهار ۱۴۰۵



مقاله پژوهشی

<https://doi.org/10.22131/sepehr.2026.2052338.3120>

پیش‌بینی وقوع سیل در حوضه آبریز سد طرق واقع در استان خراسان رضوی

مجید گودرزی*^۱، زهرا سلطانی^۲، فرخنده هاشمی قندعلی^۳

۱- (*نویسنده مسئول) دانشیار جغرافیا و برنامه‌ریزی شهری، دانشگاه شهید چمران اهواز، اهواز، ایران m.goodarzi@scu.ac.ir

۲- دانشیار جغرافیا و برنامه‌ریزی روستایی، دانشگاه شهید چمران اهواز، اهواز، ایران z.soltani@scu.ac.ir

۳- دانشجوی دکتری جغرافیا و برنامه‌ریزی شهری، دانشگاه شهید چمران اهواز، اهواز، ایران f.hashemi1401@gmail.com

چکیده

سیل یکی از مخاطرات مهم است که خسارت‌های اقتصادی و جانی زیادی به همراه دارد. یکی از راه‌های اصلی مقابله با سیل، استفاده از توانایی شبکه‌های عصبی مصنوعی در طراحی سیستم‌های هشدار مبتنی بر مدل‌های پیش‌بینی بارش- رواناب است. شبکه عصبی مصنوعی شاخه‌ای از هوش مصنوعی است که با مطالعه بر روی مغز و سیستم اعصاب در ارگانیسم‌های بیولوژیکی، شبیه‌سازی شده و در حال حاضر یکی از ابزارهای محاسباتی قدرتمند در زمینه‌های متعدد محسوب می‌شود. نمونه مطالعاتی پژوهش حاضر، حوضه آبریز سد طرق واقع در استان خراسان رضوی بوده و روش مورد استفاده برای پیش‌بینی سیل، بهره‌گیری از هوش مصنوعی است. این تحقیق پارامترهای هواشناسی، فیزیوگرافی و هیدرولوژی حوضه آبریز را با استفاده از شبکه عصبی مصنوعی، برای تعیین دبی سیلاب صورت گرفته شبیه‌سازی نموده است. از آنجا که زمان تمرکز حوضه‌های آبریز مورد بررسی کمتر از سه ساعت بوده و این به معنی آن است که زمان رسیدن بارش از نقطه بارش بر روی حوضه تا خروجی آن کمتر از سه ساعت می‌شود؛ بنابراین می‌توان این‌گونه نتیجه گرفت که هرچه میزان و شدت بارش تعداد روزهای گذشته بیشتری را در محاسبات ورودی شبکه‌های خود لحاظ کنیم، جواب‌ها از واقعیت فاصله می‌گیرند. پس بهتر است که محاسبات را با در نظر گرفتن میزان و شدت بارش حداکثر یک یا دو روز قبل انجام داد. نتایج حاصل از تحقیق نشان می‌دهند که با افزایش تعداد لایه‌های شبکه عصبی و انتخاب مناسب توابع انتقال، میزان دقت مدل بهبود می‌یابد. در حالت دو لایه‌ای، استفاده از تابع انتقال Tansig در لایه اول و Purelin در لایه دوم، همراه با در نظر گرفتن میزان و شدت بارش یک روز قبل، بهترین عملکرد را ارائه داده است. مقدار ضریب همبستگی در شرایط بهینه، به ۰/۸۱۷ در حالت کلی و ۰/۳۳۲ در مرحله آموزش رسیده است. همچنین، در شبکه‌های سه‌لایه‌ای با ترکیب توابع Tansig، افزایش تعداد نرون‌ها تا ۱۵ عدد موجب بهبود همبستگی بین خروجی شبکه و مقدار هدف شده است. با این حال، لحاظ کردن میزان بارش دو روز قبل، موجب کاهش مقدار رگرسیون در اعتبارسنجی و آزمایش شده است.

اطلاعات مقاله

تاریخ دریافت:

۱۴۰۳/۱۱/۱۳

تاریخ آخرین بازنگری:

۱۴۰۴/۱۰/۱۴

تاریخ پذیرش:

۱۴۰۴/۱۰/۱۴

تاریخ انتشار:

۱۴۰۴/۱۰/۱۷

واژه‌های کلیدی:

مخاطرات طبیعی؛

مدیریت منابع آب؛

شبکه‌های عصبی مصنوعی؛

استان خراسان رضوی

استناد به این مقاله:

گودرزی، م؛ سلطانی، ز؛ هاشمی قندعلی، ف (۱۴۰۵) پیش‌بینی وقوع سیل در حوضه آبریز سد طرق واقع در استان خراسان رضوی؛ فصلنامه علمی پژوهشی اطلاعات جغرافیایی (سپهر)، ۳۵ (۱۳۷)، ۴۴-۲۷

۱- مقدمه

سیلاب‌ها از جدی‌ترین مخاطرات طبیعی محسوب می‌شوند که اثرات مخربی بر محیط‌زیست، اقتصاد و جوامع انسانی دارند. سالانه میلیاردها دلار خسارت اقتصادی و انسانی ناشی از این پدیده در سراسر جهان گزارش می‌شود (Taye et al., 2020). شدت و فراوانی سیلاب‌ها در دهه‌های اخیر، به‌ویژه در مناطق خشک و نیمه‌خشک، به‌دلیل تغییرات اقلیمی، افزایش بارش‌های غیرقابل پیش‌بینی و تغییر در کاربری اراضی افزایش یافته است (Niu et al., 2021). در این زمینه، پیش‌بینی دقیق و به‌موقع وقوع سیلاب به‌منظور کاهش خسارات و مدیریت بهینه منابع آب، به یکی از اولویت‌های اصلی پژوهش‌های هیدرولوژیکی و مدیریت بحران تبدیل شده است.

شبکه‌های عصبی مصنوعی^۱ به‌عنوان یکی از روش‌های پیشرفته هوش مصنوعی، در سال‌های اخیر توجه گسترده‌ای را به خود جلب کرده‌اند. این روش‌ها با توانایی خود در مدل‌سازی غیرخطی روابط پیچیده میان داده‌ها، به ابزاری قدرتمند برای پیش‌بینی در سیستم‌های هیدرولوژیکی تبدیل شده‌اند (Sharma et al., 2020). به‌ویژه در مطالعات پیش‌بینی سیلاب، استفاده از ANN به‌دلیل کارایی بالا در تحلیل داده‌های زمانی و مکانی، بسیار رایج شده است. برخلاف روش‌های سنتی مدل‌سازی هیدرولوژیکی که به تعداد زیادی پارامتر و فرضیات پیچیده وابسته‌اند، شبکه‌های عصبی مصنوعی می‌توانند به‌صورت مستقیم از داده‌های مشاهده‌شده یاد بگیرند و الگوهای پنهان را شناسایی کنند (Khan et al., 2021).

حوضه‌های آبریز به‌عنوان واحدهای پایه‌ای مدیریت منابع آب، دارای ویژگی‌های منحصر به فردی هستند که بر وقوع و شدت سیلاب‌ها تأثیر می‌گذارند. در ایران، که اقلیم آن عمدتاً خشک و نیمه‌خشک است، وقوع سیلاب‌ها به‌ویژه در حوضه‌های کوچک و متوسط مانند حوضه آبریز سد طرق، چالش‌های جدی برای مدیریت منابع آب ایجاد کرده است (Moradi et al., 2021). سد طرق که در استان خراسان

رضوی و در نزدیکی شهر مشهد قرار دارد، نقش حیاتی در تأمین آب شرب و کشاورزی این منطقه ایفا می‌کند. وقوع سیلاب‌های ناگهانی در این حوضه می‌تواند تأثیرات منفی بر ذخیره آب سد، امنیت مناطق پایین‌دست و زیرساخت‌های محلی داشته باشد (Rezazadeh et al., 2022). بنابراین، توسعه ابزارهای پیش‌بینی دقیق و کارآمد برای مدیریت این حوضه آبریز ضروری است.

یکی از ویژگی‌های مهم شبکه‌های عصبی مصنوعی، توانایی آن‌ها در ترکیب داده‌های مختلف هیدرولوژیکی، اقلیمی و مکانی است. این شبکه‌ها می‌توانند داده‌های بارش، دما، پوشش گیاهی و کاربری اراضی را تحلیل کرده و پیش‌بینی‌های دقیقی درباره وقوع سیلاب ارائه دهند (Zhang et al., 2020). به‌عنوان مثال، مطالعات اخیر نشان داده‌اند که استفاده از ANN در پیش‌بینی سیلاب می‌تواند دقت پیش‌بینی‌ها را تا ۳۰ درصد نسبت به روش‌های سنتی بهبود بخشد (Gupta et al., 2019). علاوه بر این، شبکه‌های عصبی مصنوعی می‌توانند برای آموزش و به‌روزرسانی مدل‌ها از داده‌های بلادرنگ^۲ استفاده کنند، که این امر به‌ویژه در مناطق با تغییرات سریع هیدرولوژیکی، مزیت بزرگی محسوب می‌شود (Hosseini et al., 2021).

شبکه‌های عصبی مصنوعی به‌عنوان یکی از پرکاربردترین ابزارهای هوش مصنوعی، در دهه‌های اخیر پیشرفت چشمگیری داشته‌اند. این سیستم‌ها که از ساختار مغز انسان الهام گرفته‌اند، قادر به یادگیری روابط پیچیده، مدل‌سازی غیرخطی و تحلیل داده‌های بزرگ هستند (Goodfellow et al., 2016). با این حال، چالش‌هایی مانند محدودیت در یادگیری الگوهای پیچیده‌تر، نیاز به حجم بالای داده و مشکلات همگرایی، باعث شده است که پژوهشگران به سمت توسعه شبکه‌های عصبی ترکیبی^۳ روی آورند. این شبکه‌ها با ترکیب ANN با سایر روش‌ها و الگوریتم‌های یادگیری ماشین، مانند الگوریتم‌های تکاملی، مدل‌های احتمالاتی و تکنیک‌های آماری، سعی در بهبود عملکرد و افزایش دقت

2- real-time

3- Hybrid Neural Networks

1- Artificial Neural Networks - ANN

زمانی و روابط متوالی در داده‌ها را بهبود بخشید (Elman, 1990). ویژگی متمایز ENN در مقایسه با سایر شبکه‌های عصبی، قابلیت آن در مدل‌سازی داده‌های دینامیکی و سیستم‌های پیچیده است، که در آن وابستگی‌های زمانی و توالی‌ها نقش مهمی ایفا می‌کنند (Wang et al., 2021). شبکه عصبی المن از یک ساختار بازگشتی بهره می‌برد که شامل سه لایه اصلی است: لایه ورودی، لایه پنهان، و لایه خروجی. آنچه این شبکه را از سایر شبکه‌ها متمایز می‌کند، وجود یک لایه «حافظه» است که وضعیت‌های گذشته لایه پنهان را ذخیره کرده و به‌عنوان ورودی در چرخه بعدی پردازش مورد استفاده قرار می‌دهد. این حافظه به شبکه امکان می‌دهد تا اطلاعات متوالی را به‌صورت پویا ذخیره و تحلیل کند (Shi et al., 2019).

کاربردهای شبکه عصبی المن بسیار گسترده است و در حوزه‌های مختلفی مانند پیش‌بینی سری‌های زمانی، پردازش زبان طبیعی، شناسایی گفتار، و تحلیل داده‌های مالی به کار گرفته شده است (Chen et al., 2020). از آنجا که این شبکه قادر به یادگیری روابط غیرخطی و وابستگی‌های پیچیده در داده‌های متوالی است، برای حل مسائل پویا و سیستم‌های زمان‌مند بسیار مؤثر واقع شده است (Zhang et al., 2022). یکی از نقاط قوت اصلی شبکه عصبی المن، توانایی آن در مدل‌سازی روابط پیچیده با استفاده از داده‌های محدود است. این ویژگی به‌خصوص در کاربردهایی که داده‌های موجود محدود یا ناقص هستند، اهمیت دارد. با این حال، یکی از چالش‌های اصلی این شبکه، کندی همگرایی و احتمال گرفتار شدن در بهینه‌های محلی است که تلاش‌های زیادی برای بهبود این مشکلات صورت گرفته است (Li et al., 2021).

در سال‌های اخیر، بهبودهای مختلفی برای افزایش عملکرد شبکه عصبی المن ارائه شده است. از جمله این بهبودها می‌توان به ترکیب ENN با روش‌های یادگیری عمیق و الگوریتم‌های بهینه‌سازی اشاره کرد، که عملکرد

دارند (Zhang et al., 2019). شبکه‌های عصبی ترکیبی به‌ویژه در مسائل چندبعدی و پیچیده، که نیاز به تحلیل داده‌های متنوع دارند، عملکرد بهتری نشان داده‌اند. این مدل‌ها به‌گونه‌ای طراحی شده‌اند که از نقاط قوت چندین روش استفاده کرده و محدودیت‌های هر روش را کاهش دهند. به‌عنوان مثال، ترکیب شبکه‌های عصبی عمیق^۱ با الگوریتم‌های بهینه‌سازی مانند الگوریتم ژنتیک^۲ یا ازدحام ذرات^۳ می‌تواند کارایی مدل را در مسائل پیچیده بهینه‌سازی به‌طور چشمگیری افزایش دهد (Wang et al., 2020). کاربردهای شبکه‌های عصبی ترکیبی گستره وسیعی از حوزه‌ها را در بر می‌گیرد، از جمله پیش‌بینی در سیستم‌های مالی، شناسایی الگو در تصاویر پزشکی، تشخیص تقلب در تراکنش‌های بانکی و حتی پیش‌بینی آب‌وهوا (Chen et al., 2021). یکی از مزایای این رویکرد، قابلیت آن در بهبود دقت و پایداری مدل‌ها در مواجهه با داده‌های نویزی یا ناپیوسته است. درواقع، شبکه‌های ترکیبی قادرند اطلاعات را از منابع مختلف دریافت و ادغام کنند، که این امر در کاربردهای دنیای واقعی بسیار حیاتی است (Huang et al., 2022).

یکی از حوزه‌هایی که شبکه‌های عصبی ترکیبی تأثیر زیادی داشته‌اند، تحلیل داده‌های بزرگ است. با توجه به افزایش روزافزون داده‌ها در عصر حاضر، استفاده از روش‌هایی که توانایی پردازش سریع و تحلیل دقیق این داده‌ها را داشته باشند، ضروری است. شبکه‌های عصبی ترکیبی با تلفیق روش‌های مبتنی بر یادگیری عمیق و الگوریتم‌های بهینه‌سازی، راهکاری مؤثر برای تحلیل داده‌های حجیم و پیچیده ارائه کرده‌اند (Rasouli et al., 2021). شبکه عصبی المن^۴ یکی از پیشرفته‌ترین ساختارهای شبکه‌های عصبی بازگشتی^۵ است که توسط جفری المن (Jeffrey Elman) در سال ۱۹۹۰ معرفی شد. این مدل، با افزودن حافظه به ساختار شبکه، توانایی درک وابستگی‌های

1- Deep Neural Networks - DNN

2- Genetic Algorithm

3- Particle Swarm Optimization

4- Elman Neural Network - ENN

5- Recurrent Neural Networks - RNN

6- Context Layer

مطالعات پیشین کمتر مورد توجه قرار گرفته است. چهارم، تمرکز ویژه بر حوضه آبریز سد طرق، که با شرایط اقلیمی خاص خود چالش‌های منحصربه‌فردی برای پیش‌بینی سیلاب دارد، باعث ارائه راهکارهای بومی‌سازی شده و قابل اجرا در مدیریت بحران‌های محلی می‌شود. در نهایت، این تحقیق امکان به‌روزرسانی مدل‌ها با داده‌های بلندمدت را فراهم می‌آورد، که باعث افزایش دقت و پویایی پیش‌بینی‌ها در شرایط متغیر هیدرولوژیکی می‌شود.

۲- منطقه مورد مطالعه و داده‌های مورد استفاده

۲-۱- منطقه مورد مطالعه

منطقه مورد مطالعه، حوضه آبریز سد طرق واقع در استان خراسان رضوی، به دلیل ویژگی‌های خاص فیزیوگرافی و هیدرولوژیکی و اهمیت اقتصادی آن انتخاب شد. این حوضه با زمان تمرکز کمتر از سه ساعت، شرایط مناسبی برای آزمایش کارایی مدل‌های ANN در پیش‌بینی سیلاب فراهم می‌کند.

حوضه ی آبخیز سد طرق در شمال شرق ایران و جنوب شهرستان مشهد و در دامنه‌های شمال شرقی زون ساختاری بینالود واقع شده است. محدوده مطالعاتی دارای مساحت ۱۶۳/۱۲ کیلومتر مربع و بین عرض جغرافیایی شمالی ۳۶° ۶' تا ۳۶° ۱۲' و طول جغرافیایی شرقی ۵۹° ۱۷' تا ۵۹° ۳۴' واقع شده است. رودخانه طرق یکی از شاخه‌های کشف رود و تأمین کننده آب سد طرق مشهد است منطقه مورد مطالعه دارای اقلیم خشک تا نیمه خشک با میانگین دمای سالانه ۱۱/۵ درجه سلسیوس، میانگین بارش سالانه ۲۹۸/۴۵ میلیمتر و متوسط دمای کمینه سالانه ۴/۸-، متوسط دمای بیشینه سالانه ۱۸/۶۶ درجه سلسیوس است. بیشترین بارش متوسط ماهانه حوضه مربوط به ماه اسفند به میزان ۵۴/۵ میلیمتر و در ماه‌های فصل تابستان مقدار بارش کمتر از ۹ میلیمتر است. ارتفاع متوسط حوضه سد طرق ۱۷۰۰/۷ متر، حداقل ارتفاع ۱۲۶۱/۴ متر (در محل خروجی حوضه) و حداکثر ارتفاع هم ۲۲۴۰/۶ متر از سطح دریا در مناطق مرتفع غربی هست. میانگین آبدهی سالانه حوضه


آن را در مواجهه با داده‌های پیچیده و نویزی ارتقاء داده است (Huang et al., 2020). مطالعات پیش‌بینی سیلاب به‌ویژه در مناطق حساس مانند حوضه‌های آبریز ایران از اهمیت بالایی برخوردار است. وقوع سیلاب در این مناطق نه تنها به کاهش کیفیت منابع آب و خسارات زیرساختی منجر می‌شود، بلکه تهدیدی جدی برای حیات اقتصادی و اجتماعی جامعه محلی محسوب می‌شود (Alizadeh et al., 2020). در این راستا، استفاده از ابزارهای پیشرفته مانند ANN می‌تواند به بهبود دقت پیش‌بینی‌ها و مدیریت بهتر بحران کمک کند. این مطالعه همچنین به غنای پژوهش‌های موجود در زمینه پیش‌بینی سیلاب با استفاده از تکنیک‌های هوش مصنوعی کمک خواهد کرد و می‌تواند الگویی برای مطالعات مشابه در سایر حوضه‌های آبریز ایران ارائه دهد. در این پژوهش، تلاش شده است تا با استفاده از شبکه‌های عصبی مصنوعی، وقوع سیلاب در حوضه آبریز سد طرق پیش‌بینی شود. مطالعه حاضر از داده‌های هواشناسی و هیدرولوژیکی مرتبط استفاده می‌کند تا بتواند با ارائه یک مدل دقیق، به مدیریت بهینه منابع آب و کاهش خسارات سیلاب کمک کند. هدف اصلی این پژوهش، توسعه مدلی است که با استفاده از قابلیت‌های ANN، بتواند وقوع سیلاب را به صورت دقیق و به موقع پیش‌بینی کرده و اطلاعات ارزشمندی برای تصمیم‌گیری مدیران منابع آب ارائه دهد. نوآوری این تحقیق در مقایسه با سایر پژوهش‌های مشابه در چندین جنبه کلیدی نهفته است. نخست، این مطالعه با استفاده از شبکه‌های عصبی ترکیبی و مدل‌های بهینه‌سازی، دقت پیش‌بینی سیلاب را بهبود می‌بخشد، در حالی که بسیاری از پژوهش‌های پیشین تنها به شبکه‌های عصبی ساده متکی بوده‌اند. دوم، تحقیق حاضر از داده‌های چندبعدی شامل پارامترهای هیدرولوژیکی، اقلیمی و مکانی بهره می‌برد و از رویکرد یکپارچه برای تحلیل و پیش‌بینی سیلاب استفاده می‌کند. سوم، استفاده از شبکه عصبی المن (ENN) برای مدل‌سازی وابستگی‌های زمانی در داده‌های سیلاب، قابلیت پیش‌بینی بلندمدت را تقویت می‌کند، که در

۲-۲- داده‌های مورد استفاده


داده‌های مورد استفاده در این تحقیق شامل داده‌های هواشناسی (مانند بارش و دما)، داده‌های هیدرولوژیکی (دبی جریان)، و داده‌های فیزیوگرافی حوضه (مانند مساحت، شیب و طول رودخانه) بوده است. داده‌های بارش به صورت روزانه از ایستگاه‌های هواشناسی معتبر جمع‌آوری و مورد ارزیابی کیفیت قرار گرفت. برای کاهش عدم قطعیت در داده‌ها، از روش‌های آماری برای تصحیح و پرکردن داده‌های ناقص استفاده شد.

آبخیز ۶۰ متر مکعب بر ثانیه و میانگین آبدهی ماه‌های سیلابی حوضه آبخیز شامل اسفند، فروردین و اردیبهشت به ترتیب برابر با ۱/۲۴، ۱/۵ و ۰/۹۴۸ متر مکعب بر ثانیه برآورد شده است. میانگین حجم آورد سالانه حوضه آبخیز ۱۴/۴۸ میلیون متر مکعب و میانگین و میانگین آورد ماه‌های سیلابی حوضه آبخیز شامل اسفند، فروردین و اردیبهشت به ترتیب برابر با ۳/۱۱، ۴/۰۲ و ۲/۵۴ میلیون متر مکعب هستند (سرایی، دستورانی و زرین، ۱۳۹۹).

موقعیت جغرافیایی و نقشه زمین‌شناسی حوضه‌ی آبخیز مورد مطالعه در نگاره‌های (۱) و (۲) ارائه شده است.



نگاره ۱: موقعیت جغرافیایی حوضه آبریز طرق در ایران (جوانبخت و همکاران، ۱۳۸۷)



نگاره ۲: نقشه زمین‌شناسی مشهد و منطقه مورد مطالعه (جوانبخت و مکاران، ۱۳۸۷)

۳- روش‌شناسی تحقیق

شدند تا عدم قطعیت به حداقل برسد. پس از آن داده‌ها نرمال‌سازی شده و در بازه ۰،۱۰،۱۰،۱ قرار گرفتند تا اثر اختلاف ابعاد فیزیکی متغیرها از بین برود. با توجه به زمان تمرکز کوتاه حوضه، داده‌های بارش روز جاری و روز قبل به‌عنوان ورودی مدل انتخاب شد. طراحی مدل‌های شبکه عصبی در دو ساختار دو لایه‌ای و سه لایه‌ای انجام گرفت؛ در ساختار دوم برای افزایش دقت پیش‌بینی از توابع انتقال Tansig و Purelin استفاده شد. آموزش شبکه با الگوریتم پس‌انتشار خطا^۱ و تابع بهینه‌سازی^۲ صورت گرفت و معیار توقف بر اساس کمینه شدن میانگین مربعات خطا^۳ تعیین شد. داده‌ها به سه بخش آموزش (۷۰ درصد)، اعتبارسنجی داخلی (۱۵ درصد) و آزمون نهایی (۱۵ درصد) تقسیم شدند

این تحقیق از نوع کاربردی-توسعه‌ای است و بر پایه تحلیل‌های عددی، داده‌های هواشناسی و هیدرولوژیکی واقعی و طراحی مدل‌های هوش مصنوعی انجام گرفته است. در این پژوهش داده‌های بارش، دما و رطوبت نسبی از ایستگاه‌های سینوپتیک و باران‌سنجی منطقه برای دوره زمانی سال‌های ۲۰۱۰ تا ۲۰۲۳ گردآوری و کنترل کیفی شدند. همچنین داده‌های دبی جریان خروجی از ایستگاه هیدرومتری پایین‌دست و داده‌های فیزیوگرافی شامل مدل ارتفاع رقومی، شیب، جهت جریان و کاربری اراضی از منابع رسمی و داده‌های سنجش‌ازدور استخراج شد. برای اطمینان از صحت داده‌ها از آزمون‌های آماری نرمال بودن، میانگین متحرک و حذف داده‌های پرت استفاده شد و داده‌های ناقص با میانگین‌گیری وزنی و رگرسیون خطی تکمیل

1- Backpropagation

2- Levenberg-Marquardt (LM)

3- MSE

تأکید دارد که اعتبار مدل ANN، پیش از آنکه در گرو معماری شبکه باشد، مرهون انضباط داده‌ها و سازگاری آن‌ها با منطق هیدرولوژیکی حوضه است (ارجاع: نگاره مدل مفهومی پژوهش).

در نیمه دوم این مدل مفهومی، مسیر پژوهش از «انتخاب متغیرهای ورودی» و «طراحی ساختار شبکه» به سمت مراحل آموزش، ارزیابی عملکرد و در نهایت گزینش مدل بهینه هدایت می‌شود. این بخش که در واقع ستون فقرات تصمیم‌گیری علمی مقاله حاضر را تشکیل می‌دهد، آشکار می‌کند که انتخاب نهایی نه بر پایه آزمون و خطاهای تصادفی، بلکه با تکیه بر حداقل‌سازی خطاهای آماری نظیر RMSE و MAE و بیشینه‌سازی توان تبیین‌گری (R^2) انجام گرفته است. تفکیک آگاهانه میان «مقایسه مدل‌ها» و «انتخاب مدل نهایی» در این نگاره، به‌طور ضمنی بر ضرورت کنترل پدیده بیش‌برازش^۱ و واکاوی دقیق ساختارهای مختلف، اعم از تعداد لایه‌ها و تنوع توابع انتقال نظیر Tansig و Purelin، دلالت دارد. به‌این ترتیب، خروجی نهایی پژوهش به مدلی پیوند می‌خورد که نه تنها در شاخص‌های آماری برتری دارد، بلکه از منظر انسجام با رفتار زمانی سامانه هیدرولوژیکی نیز کاملاً قابل دفاع و توجیه‌پذیر است.

۴- بحث و یافته‌های تحقیق

۴-۱- آماده سازی شبکه و ارزیابی عملکرد آن

در نگاره (۴) آماده سازی شبکه، تعیین نوع شبکه و مقایسه عملکرد validation.test.train در مقایسه با بهترین عملکرد در طول ۱۴ دوره در لایه‌های مختلف نشان داده شده است. در مرحله بعد با انتخاب ماتریس صحت‌سنجی به‌عنوان ورودی، عملیات شبیه‌سازی انجام گرفته و داده و خروجی آن با ماتریس خروجی شبکه یکی می‌شود. با این کار ابعاد ماتریس خروجی شبکه و ماتریس خروجی صحت‌سنجی یکی می‌شوند. در ادامه با بررسی نمودار خطاها و با مقایسه نتایج به‌دست آمده در هر دوره و تغییر



و برای جلوگیری از بیش‌برازش، روش‌های Early Stopping و Cross Validation مورد استفاده گرفتند. دقت مدل‌ها با شاخص‌های آماری ضریب تعیین (R^2)، میانگین قدر مطلق خطا (MAE) و جذر میانگین مربعات خطا (RMSE) ارزیابی شد. نتایج نشان داد ساختار سه‌لایه با ترکیب توابع انتقال Tansig و Purelin بهترین عملکرد را داشته و مقدار R^2 کلی آن ۰/۸۱۷ بوده است. تمامی تحلیل‌ها با استفاده از نرم‌افزار MATLAB R2023b و جعبه‌ابزار Neural Network Toolbox انجام شد و داده‌های مکانی نیز با ArcGIS 10.8 و ENVI 5.6 پردازش شدند. همچنین تحلیل‌های آماری و صحت‌سنجی نهایی با SPSS 26 صورت گرفت. در مجموع، فرایند پژوهش شامل گردآوری و پالایش داده‌ها، طراحی مدل‌های ANN، آموزش و آزمون مدل‌ها با داده‌های واقعی، ارزیابی دقت پیش‌بینی و انتخاب مدل بهینه بوده است. این فرایند نظام‌مند، چارچوبی علمی برای استفاده از هوش مصنوعی در مدیریت مخاطرات طبیعی ارائه می‌دهد و می‌تواند مبنایی برای توسعه سامانه‌های هشدار سریع سیلاب در سایر مناطق کشور باشد. مدل مفهومی در نگاره ۳، چارچوب کلان این مطالعه را در قالب یک زنجیره منطقی از «مسئله‌محوری تا تصمیم‌سازی» مفصل‌بندی می‌کند. این فرایند با تبیین هدف کلیدی پژوهش، یعنی پیش‌بینی دبی اوج سیلاب از طریق شبکه‌های عصبی مصنوعی، آغاز شده و با تدقیق در ابعاد مکانی، زمانی و ویژگی‌های حوضه، ماهیت فیزیکی سامانه را به‌عنوان بستر اصلی تبیین مدل‌سازی تثبیت می‌نماید. بلوک اختصاصی «داده‌های ورودی» در این نگاره به‌وضوح نشان می‌دهد که مدل‌سازی حاضر فراتر از یک رویکرد خروجی‌محور صرف، بر پیوند وثیق میان متغیرهای هواشناسی و ویژگی‌های هیدرولوژیکی استوار است. در ادامه، مراحل «آماده‌سازی، کنترل کیفیت و پیش‌پردازش»، با هدف پالایش نويزها و ارتقای قابلیت تعمیم مدل طراحی شده‌اند تا از ورود هرگونه خطای سازمان‌یافته به فرایند یادگیری جلوگیری شود. از منظر روش‌شناختی، این توالی گام‌به‌گام بر این اصل کلاسیک در مدل‌سازی‌های داده‌محور



نگاره ۳: مدل مفهومی پژوهش

۴-۲- امتیاز شبکه‌های عصبی پیش‌خور
برای اینکه محاسبات شبکه عصبی با توجه به نوع الگویی که به کار گرفته شده است، داده‌ها در یک زمان واحد گرفته و پردازش شوند و همچنین خطای محاسبه به حداقل برسد، از شبکه‌های پس‌انتشار استفاده می‌شود. چرا که در این نوع

ورودی‌ها برای دوره بعد بهترین ساختار شبکه تعیین می‌شود. در هر دوره برای اطمینان بیشتر ضریب همبستگی مشخص خواهد شد که هر چه قدر این ضریب به یک نزدیک‌تر باشد اطلاعات به‌دست‌آمده دقیق‌تر و در نتیجه کارایی شبکه بهتر خواهد شد.



نگاره ۴: ارزیابی روند آموزش شبکه عصبی بر اساس عملکرد مجموعه‌های آموزش، اعتبارسنجی، آزمون و تکامل خطای خروجی

بر آن هنگامی که میزان و شدت بارش دو روز قبل را در نظر بگیریم با افزایش میزان رگرسیون در حالت آموزش و کاهش آن در حالت اعتبارسنجی و آزمایش مواجه هستیم و در حالت مجموع به غیر از حالتی که تابع انتقال لایه خروجی از نوع purelin است، شاهد افزایش میزان رگرسیون هستیم. اما با افزایش میزان نرون‌ها به ۱۵ عدد در حالتی که تابع انتقال لایه اول از نوع Tansig باشد جواب‌های عمل آموزش به‌خوبی بادی‌های اوج ما سازگار است. رابطه‌ای که در حالت در نظر گرفتن میزان و شدت بارش یک روز قبل بهتر هم می‌شود چرا که در این حالت در قسمت اعتبارسنجی و آزمایش به جواب‌ها و روابط خوبی بین خروجی و ماتریس خروجی خود می‌رسیم که این رابطه در حالت آموزش گرفتن میزان و شدت بارش دو روز قبل در حالت آزمایش و اعتبارسنجی و مجموع بدتر است. بنابراین درحالتی که شبکه دو لایه است بهترین حالت استفاده از تابع انتقال Tansig در لایه اول و Purelin در لایه دوم و لحاظ کردن میزان و شدت بارش یک روز اخیر است.


در شبکه‌های پسانتشار سه لایه در حالتی که لایه اول پنج نرون و لایه دوم شش نرون دارد، خروجی شبکه و هدف در کلیه حالات زمانی که هر سه تابع انتقال از نوع Tansig باشد، با یکدیگر نسبت مستقیم دارند که درحالت

شبکه‌ها همه رخدادهای سیل در ابتدا به شکل یک مجموعه در نظر گرفته می‌شوند و عملیات بر روی تمام آن‌ها در یک زمان واحد انجام می‌گیرد و از طرفی در الگویی که به کار گرفته شده است هم ورودی و هم دبی اوج سیلاب مشاهده و اندازه‌گیری شده - که همان مقادیر هدف هستند - لحاظ شده است و به دنبال دبی اوج محاسباتی شبکه عصبی هستیم و در واقع هدف معلومی وجود دارد که می‌خواهد تحقق پیدا کند. پس الگوی شبکه‌های پیش‌خور الگوی مورد انتظار ما هست. از طرفی چون شبکه‌های پسانتشار با پسانتشار خطا میزان آن را به حداقل می‌رسانند، بنابراین بهترین نوع شبکه، شبکه پیش‌خور پسانتشار است. امتیاز شبکه‌های عصبی پیش‌خور با توابع انتقال، شدت بارش‌های متفاوت و تعداد نرون‌های مختلف در نگاره‌های (۵) تا (۱۰) نشان داده شده‌اند.


با افزایش تعداد لایه‌ها شاهد افزایش میزان رگرسیون به‌خصوص در حالتی که تابع انتقال لایه خروجی ما purelin است، هستیم. این امر به دلیل برد بیشتر تابع Purelin و افزایش دامنه تغییرات جواب‌های ما هست. این افزایش همچنین در میزان ضریب هم بستگی تا حدود ۰/۶۳ در حالتی که تعداد نرون‌ها شش و تابع انتقال لایه اول Tansig و تابع انتقال لایه دوم purelin است، به چشم می‌خورد. علاوه

آموزش رگرسیونی در حدود $0/632$ و در حالت کلی $0/817$ هستند. این مقدار زمانی که مقدار شدت بارش دو روز قبل هم لحاظ شوند کاهش می‌یابند. اما در این نوع شبکه آنچه مشهود است رگرسیون بالا در حالات آموزش و اعتبارسنجی هست. با افزایش تعداد نرون‌ها به میزان ۶ و ۱۰ در لایه‌های اول و دوم باز هم در حالتی که تابع انتقال دو لایه اول Tansig باشد خروجی شبکه و تابع هدف در حالت آزمایش و اعتبارسنجی به خوبی با یکدیگر نسبت مستقیم دارند که در این حالات با اضافه کردن مقدار و شدت بارش دو روز قبل شیب خط رابطه‌ی بین خروجی شبکه و هدف به یک نزدیک‌تر و رگرسیون در دو حالت آموزش و مجموع بالاتر می‌رود. اما در حالت آزمایش رابطه بین خروجی و تابع هدف آن هم در شرایطی که میزان و شدت بارش دو روز قبل هم در نظر گرفته شود معکوس ولی


در حالت آزمایش مستقیم با شیب کم است (دارای رگرسیون $0/251$ در حالتی که دو لایه اول Tansig باشد و $0/425$ در حالتی که هر سه لایه Tansig باشند). همچنین در حالت اعتبارسنجی میزان رگرسیون رابطه بین ماتریس هدف و خروجی شبکه معکوس و یا نزدیک به صفر است. لازم به ذکر است که در حالتی که لایه یا لایه‌های اولیه دارای تابع انتقال purelin باشند ضریب هم بستگی بالاتری داریم و در حالت آموزش، رگرسیون بهتر از بقیه حالات است که با لحاظ کردن میزان و شدت بارش دو روز قبل این رابطه کمی بهتر می‌شود ولی در بقیه حالات رگرسیون بدتر و یاحتی رابطه بین خروجی شبکه و هدف معکوس می‌شود. در ادامه نمودار میزان خطا در حالت‌های مختلف ارائه شده است (نگاره ۱۱).




نگاره ۵: شبکه تک لایه با تابع انتقال Tansig و در نظر گرفتن میزان و شدت بارش یک روزه




نگاره ۶: شبکه تک لایه با تابع انتقال Logsig و در نظر گرفتن میزان و شدت بارش یک روزه




نگاره ۷: شبکه دو لایه با شش نرون و تابع انتقال T-P و در نظر گرفتن میزان و شدت بارش یک روزه




نگاره ۸: شبکه دو لایه با ۶ نرون و تابع انتقال T-P و در نظر گرفتن میزان و شدت بارش دو روزه



نگاره ۹: شبکه دو لایه با ۱۵ نرون و تابع انتقال T-T و در نظر گرفتن میزان و شدت بارش یک روزه



نگاره ۱۰: شبکه دو لایه با ۱۵ نرون و تابع انتقال T-T و در نظر گرفتن میزان و شدت بارش دو روزه



نگاره ۱۱: مقایسه میزان خطای شبکه عصبی مصنوعی تحت ساختارهای مختلف لایه و تابع انتقال

۵- نتیجه گیری

شبکه‌های عصبی از پرکاربردترین موضوعات مطرح در زمینه طراحی سیستم‌های هوشمند با الهام از طبیعت هستند که جایگاه مناسبی در علوم مختلف دارند. با توجه به مقایسه‌هایی که در مورد نوع شبکه، تعداد لایه‌ها، نوع توابع انتقال و تعداد نرون‌ها در لایه‌های مختلف و تعداد روزهای در نظر گرفته شده برای میزان و شدت بارش انجام گرفت به این نتیجه می‌رسیم که شبکه‌های پیش‌خور به دلیل آنکه مقدار خطا را در مراحل مختلف انتشار داده و باعث حداقل شدن میزان خطا می‌شوند، بهترین نوع شبکه در کارهای هیدرولوژی هستند و آن دسته از شبکه‌هایی که لایه‌های ابتدایی‌شان دارای تابع انتقال از نوع Tansig باشند، بهترین آرایش تابع انتقال را برای رسیدن به جواب واقعی دارند.

البته در برخی از آرایش شبکه‌ها در صورتی که تمام لایه‌ها یا لایه‌های میانی دارای تابع انتقال از نوع Tansig باشند رابطه بین خروجی شبکه و ماتریس هدف مستقیم‌تر و شیب خط آن به یک نزدیک‌تر است. از آنجا که زمان تمرکز حوضه‌های آبریز مورد بررسی کمتر از سه ساعت برآورد می‌شود و این به معانی آن است که زمان رسیدن بارش از نقطه بارش بر روی حوضه تا خروجی آن کمتر از سه ساعت است بنابراین می‌توان نتیجه گرفت که هرچه میزان و شدت بارش تعداد روزهای گذشته بیشتری در محاسبات ورودی شبکه‌ها لحاظ شود، جواب‌ها از واقعیت فاصله می‌گیرد. پس بهتر است که محاسبات را با در نظر گرفتن میزان و شدت بارش حداکثر یک یا دو روز قبل انجام دهیم. در بیشتر موارد هم این مطلب عینیت می‌یابد که هر چه تعداد روز قبل کمتری را در نظر بگیریم شیب خط رابطه بین خروجی شبکه و ماتریس هدف به یک نزدیک‌تر می‌شود.

در شبکه‌های دو لایه ملاحظه می‌شود هنگامی که تابع انتقال لایه اول از نوع Tansig و لایه دوم از نوع purelin باشد و میزان و شدت بارش تنها همان روز سیلاب و روز قبل در نظر گرفته شود جواب شبکه با خروجی رابطه مستقیم داشته

و به واقعیت نزدیک‌تر است و با افزایش تعداد نرون‌ها در این حالت نتیجه به خصوص در حالات آموزش و حالت کلی به واقعیت نزدیک‌تر می‌شود.

در شبکه‌های سه لایه با آرایش تابع انتقال T-T-T هر چه تعداد نرون‌ها بیشتر شود، رگرسیون افزایش یافته و جواب‌های ما به خصوص در حالتی که فقط میزان و شدت بارش روز سیلاب و روز قبل آن را در نظر می‌گیریم به واقعیت نزدیک‌تر می‌شود. در همین شبکه‌های سه لایه وقتی تعداد نرون‌ها در لایه اول ۱۰ و در لایه دوم ۱۵ و آرایش تابع انتقال به شکل P-T-P باشد و شدت و میزان بارش یک روزه را در نظر بگیریم جواب‌های ما به واقعیت نزدیک‌تر است.

با افزایش تعداد لایه‌ها به چهار لایه ملاحظه می‌شود که اگر تابع انتقال در هر چهار لایه Tansig باشد جواب‌های ماتریس خروجی شبکه و هدف با یکدیگر نسبت معکوس پیدا می‌کنند لذا پیشنهاد می‌شود از آرایشی استفاده شود که حتی‌الامکان دو لایه انتهایی آن از نوع purelin باشد.

با تغییر شبکه به شبکه آبشاری پیش‌خور ملاحظه می‌شود که شبکه چهار لایه با آرایش تابع انتقال P-T-P-P به غیر از حالت اعتبارسنجی در بقیه موارد نسبت مستقیم خود را به خوبی حفظ کرده که این رابطه با در نظر گرفتن میزان و شدت بارش دو روز اخیر بدتر می‌شود.

نتیجه اینکه از آنجا که زمان تمرکز حوضه‌های آبریز کم هست، احتساب تنها میزان و شدت بارش روز سیلاب و روز قبل از آن کفایت می‌کند و در عمل هم در بیشتر اوقات ثابت شد و شبکه ما در لایه‌های ابتدایی با تابع انتقال Purelin و در لایه‌های انتهایی با تابع انتقال Tansig بهتر جواب می‌دهد. به این ترتیب پیشنهاد می‌شود تابع انتقال خود را با توجه به این مطلب تنظیم کنیم و در شبکه‌های آبشاری بهتر است در لایه‌های میانی از تابع انتقال Tansig و در شبکه‌های پس انتشار در لایه‌های اولیه بهتر است که از تابع انتقال Tansig استفاده کنیم. علاوه بر آن در محاسبات سیلاب بهتر است از شبکه‌های پس انتشار سه لایه یا چهار لایه و یا شبکه‌های آبشاری پیش‌خور چهار لایه استفاده کنیم چرا که جوابشان

و احتمال بیش‌برازش (Overfitting) از جمله محدودیت‌های این روش‌ها هستند که در مطالعات آتی باید مورد توجه قرار گیرند. تحقیقات آینده می‌توانند با ترکیب ANN با مدل‌های فیزیکی-مفهومی، مانند مدل‌های هیدرولوژیکی توزیعی، به بهبود عملکرد مدل‌های پیش‌بینی سیلاب کمک کنند. همچنین، استفاده از داده‌های سنجش از دور و یادگیری عمیق می‌تواند دقت پیش‌بینی‌ها را بیشتر ارتقاء دهد.

به‌طور کلی، این پژوهش نشان داد که شبکه‌های عصبی مصنوعی به‌عنوان یک روش نوین و کارآمد می‌توانند به‌طور مؤثری در پیش‌بینی وقوع سیلاب در حوضه‌های آبریز مورد استفاده قرار گیرند. این یافته‌ها می‌توانند راهگشای مدیران منابع آب و برنامه‌ریزان شهری برای کاهش اثرات مخرب سیلاب و اتخاذ راهکارهای مناسب برای مدیریت بحران باشند.

تعارض منافع

در این پژوهش، حامی مالی و تعارض منافع وجود ندارد.

References

- 1- Alizadeh, A., & Mohammadi, M. (2021). Hybrid ANN models for industrial process optimization. *International Journal of Applied Artificial Intelligence*, 35(8), 563–578.
- 2- Alizadeh, M., Soltani, M., & Mohammadi, M. (2020). Flood prediction in arid regions using machine learning techniques. *Journal of Hydrology*, 589, 125348.
- 3- Chen, Y., Wang, S., & Li, H. (2021). Hybrid neural networks for complex data modeling: Advances and applications. *Artificial Intelligence Review*, 54(3), 1671–1693.
- 4- Dawson, C.W., Abrahart, R.J., & See, L.M. (2007). HydroTest: a web-based toolbox of evaluation metrics for the standardized assessment of hydrological forecasts. *Environmental Modelling & Software*, 22(7), 1034-1052.
- 5- De Carlo, E.H., & Anthony, S.S. (2002). Spatial and temporal variability of trace element concentrations in an urban subtropical watershed, Honolulu, Hawaii. *Applied Geochemistry*, 17, 475-492.
- 6- Goodfellow, I., Bengio, Y., & Courville, A. (2016). *Deep learning*. MIT Press.
- 7- Govindaraju, R.S. (2000). *Artificial neural networks in*

به واقعیت مورد انتظار ما نزدیک‌تر است. استفاده از داده‌های بارش روز سیلاب و روز قبل از آن، به دلیل زمان تمرکز کم حوضه، کفایت می‌کند. افزایش تعداد نرون‌ها در شبکه‌های دو و سه لایه منجر به افزایش دقت پیش‌بینی شد، به‌خصوص زمانی که تنها داده‌های بارش دو روز اخیر به‌عنوان ورودی شبکه مورد استفاده قرار گرفتند. مقایسه نتایج این مطالعه با پژوهش‌های پیشین نشان می‌دهد که استفاده از روش‌های هوش مصنوعی در پیش‌بینی سیلاب در مقایسه با روش‌های کلاسیک نظیر مدل‌های هیدرولوژیکی سستی (مانند HEC-HMS و SWAT) از دقت بالاتری برخوردار است. به‌عنوان مثال، تحقیقات Sharma et al. (2020) و Khan et al. (2021) نیز کارایی بالای شبکه‌های عصبی مصنوعی را در پیش‌بینی سیلاب تأیید کرده‌اند. علاوه بر این، مطالعه‌ای که توسط Zhang et al. (2020) انجام شد، نشان داد که ترکیب ANN با سایر روش‌های یادگیری ماشین مانند الگوریتم‌های ژنتیک و ازدحام ذرات، دقت پیش‌بینی را تا ۳۰ درصد افزایش می‌دهد. نتایج مطالعه حاضر نیز هم‌راستا با این یافته‌ها بوده و نشان داد که استفاده از مدل‌های ترکیبی می‌تواند عملکرد بهتری در پیش‌بینی سیلاب ارائه دهد. همچنین، یافته‌های این پژوهش با مطالعات Hosseini et al. (2021) و Rezazadeh et al. (2022) که تأثیر تغییرات اقلیمی و تغییرات کاربری اراضی را بر شدت سیلاب‌ها بررسی کرده‌اند، همخوانی دارد. مدل پیشنهادی توانست اثر این متغیرها را در پیش‌بینی وقوع سیلاب لحاظ کند و دقت نتایج را بهبود بخشد. به‌علاوه، نتایج این مطالعه بر کارهای Goodfellow et al. (2016) و Wang et al. (2020) که به بررسی عملکرد شبکه‌های عصبی ترکیبی در تحلیل داده‌های پیچیده پرداخته‌اند، تأکید دارد و نشان می‌دهد که استفاده از این روش‌ها در پیش‌بینی سیلاب می‌تواند به افزایش دقت و کاهش خطای پیش‌بینی منجر شود. با این حال، چالش‌هایی نیز در استفاده از شبکه‌های عصبی مصنوعی برای پیش‌بینی سیلاب وجود دارد. نیاز به حجم بالای داده‌های آموزشی، حساسیت مدل‌ها به داده‌های نویزی

Journal of Hydrologic Engineering, 5(2), 162—171.

18- Rezazadeh, R., Ghasemi, H., & Amini, K. (2022). Flood vulnerability assessment in urban basins: A focus on ANN-based models. *Urban Water Journal*, 19(1), 123-136.

19- Sahoo, G.B., & Ray, C. (2006). Flow forecasting for a Hawaii stream using rating curves and neural networks. *Journal of Hydrology*, 317, 63-80.

20- Sarabi, M., Dastorani, M. T. and Zarrin, A. (2021). The Impact of Future Climate Change on Hydrological Response in Torogh Dam Watershed, Mashhad. *Journal of Meteorology and Atmospheric Science*, 3(4), 310-330. doi: 10.22034/jmas.2021.297763.1149 [In Persian]

21- Sharma, V., Prasad, R., & Gupta, R. (2020). Advances in flood prediction using machine learning models. *Environmental Earth Sciences*, 79(3), 88.

22- Taye, M., Ochoa-Rodriguez, S., & Willems, P. (2020). Impact of climate variability on flood prediction models: An ANN approach. *Journal of Hydrometeorology*, 21(7), 1367-1380.

23- Wang, J., He, H., & Ma, J. (2020). Optimization of hybrid neural networks for real-world applications. *Journal of Computational Intelligence*, 36(4), 853–870.

24- Zhang, J., Chen, Z., & Liu, Y. (2020). Application of neural networks in hydrological modeling. *Water Science and Technology*, 82(11), 2049-2060.

25- Zhang, Y., Liu, Q., & Sun, W. (2019). Hybrid neural network models for time-series prediction: A review. *Neurocomputing*, 347, 65–80.

26- Zhou, H., Zhang, S., & Hu, J. (2020). Hybrid architectures of neural networks for improved prediction in dynamic systems. *Neural Computing and Applications*, 32(5), 1241–1253.

27- Zhu, F., Wei, Q., & Liu, P. (2019). Advances in hybrid deep learning frameworks: A survey. *Pattern Recognition Letters*, 125, 93–101.

hydrology. II: hydrologic applications. *Journal of Hydrologic Engineering*, 5(2), 124-137.

8- Gupta, P., Kumar, A., & Singh, R. (2019). Application of artificial neural networks in flood forecasting: A case study. *Water Resources Management*, 33(3), 1025–1040.

9- Hosseini, S., Khalili, M., & Dehghan, M. (2021). Real-time flood prediction using ANN models: An Iranian case study. *Environmental Modelling & Software*, 145, 105243.

10- Hosseini, S.A., Ishaghian, K., & Saidi, H. (2018). Hydrological studies of Nishabur plain and Jalge Rokh. The second volume, studies of Khorasan water resources. (in Persian)

11- Huang, X., Zhang, T., & Wu, L. (2022). Hybrid deep neural networks for image recognition: A comprehensive review. *IEEE Transactions on Neural Networks and Learning Systems*, 33(2), 456–470.

12- Javanbakht, M., Mousavi Harami, S. R., Torshizian, H., Sharifi, E., & Sokhtanlou, H. (2008). Estimation of sediment and investigation of debris flow trends in the Toroq Dam watershed with emphasis on the Moghan-Kartian sub-basin. *Journal of Geotechnical Geology*, 4(2), 97–107. [In Persian]

13- Khan, S., Ahmad, I., & Ashraf, S. (2021). Application of ANN in flood prediction under changing climatic conditions. *Journal of Hydrology and Environment Research*, 9(4), 187-203.

14- Moradi, H., Jahanbakhsh, S., & Rezaei, R. (2021). Evaluating flood risk in semi-arid basins using ANN. *Hydrological Sciences Journal*, 66(2), 253–269.

15- Niu, X., Li, J., & Zhao, W. (2021). Flood risk management using artificial intelligence techniques. *Science of the Total Environment*, 764, 142868.

16- Rasouli, M., Asadi, S., & Mohammadi, K. (2021). Big data analysis using hybrid neural networks: Opportunities and challenges. *Expert Systems with Applications*, 171, 114580.

17- Ray, C., & Klindworth, K.K. (2000). Neural networks for agrichemical vulnerability assessment of rural private wells.

COPYRIGHTS

©2026 by the authors. Published by National Geographical Organization. This article is an open access article distributed under the terms and conditions of the Creative Commons [Attribution-NoDerivs 4.0 International \(CC BY-ND 4.0\)](https://creativecommons.org/licenses/by-nd/4.0/).

